

Mika Peltoperä

LÄMMITYSENERGIANKULUTUKSEN ANALYSOINTI TILASTOMENETELMILLÄ

LÄMMITYSENERGIANKULUTUKSEN ANALYSOINTI TILASTOMENETELMILLÄ

Mika Peltoperä
Opinnäytetyö
Kevät 2014
Automaatiotekniikan koulutusohjelma
Oulun ammattikorkeakoulu

TIIVISTELMÄ

Oulun ammattikorkeakoulu
Automaatiotekniikan koulutusohjelma

Tekijä: Mika Peltoperä
Opinnäytetyön nimi: Lämmitysenergiankulutuksen analysointi tilastomenetelmillä
Työn ohjaaja: Timo Heikkinen, Teemu Korpela
Työn valmistumislukukausi ja -vuosi: Kevät 2014
Sivumäärä: 42 + 9 liitettä

Opinnäytetyö tehtiin osana Oulun ammattikorkeakoulun Sula-hanketta. Työssä analysoidaan erään Haukiputaalla sijaitsevan autotallin energiankulutusta klassisella aikasarja-analyysillä, tarkastellaan lämpötilaeron vaikutusta sähkönkulutukseen sekä tehdään lineaariseen regressioanalyysiin perustuvia ennusteita. Ennusteita tehtiin sähkönkulutuksella, jossa selittävänä muuttujana oli lämpötilaero, sekä lämpökonduktanssilla, jossa selittävänä muuttujana oli aika.

Tavoitteena oli kehittää ohjelmallinen toteutus, jolla voidaan havaita normaalista kohonnut lämmityslaitteiden sähkönkulutus. Ohjelma tuli voida suorittaa automaattisesti tietyin väliajoin Sulan palvelimella.

Aikasarja-analyysin perusteella havaittiin autotallin talven sähkönkulutuksessa olevan trendin ja satunnaisuuden komponentit. Selityskertoimen avulla todettiin lämpötilaerolla olevan lineaarinen riippuvuus sähkönkulutukseen.

Ennusteissa, joissa selittävänä muuttujana oli lämpötilaero, saatiin ennusteita, jotka vastaavat hyvin sähkönkulutusta edellisien saman lämpötilaeron keskimääräiseen kulutukseen. Huonona puolena oli hidas sopeutuminen, jos lämmityskokonaisuutta vaihdettiin. Ennustetapa toimii hyvin, mikäli laitekokonaisuutta ja termostaattien asetuksia ei muutella.

Lämpökonduktanssin ennusteissa saatiin nopeampi reagointi lämmityslaittekokonaisuuden vaihteluihin, mutta käyttäessä pientä otoskokoa, ennusteet voivat reagoida liian nopeasti, jolloin asetettu tavoite ei täyty. Ennusteella ei tule ennustevälin ylityksiä, mikäli sähkönkulutus kasvaa pikkuhiljaa. Ennustetapa soveltuu hyvin tavoitteeseen, kun käytetään isoa otantamäärää.

Opinnäytetyössä saatiin hyvä yleiskuva siitä, miten kohteen sähkönkulutus käyttäytyy talvisin, sekä luotiin sovellus, jolla voidaan havaita äkillisesti kasvanut sähkönkulutus.

Asiasanat: Energiankulutus, konduktanssi, lämpötilaero, aikasarja-analyysi

ABSTRACT

Oulu University of Applied Sciences
Degree programme in Automation

Author: Mika Peltoperä

Title of thesis: Statistical Analysis of Energy Consumption of Heating Devices

Supervisor: Timo Heikkinen, Teemu Korpela

Term and year when the thesis was submitted: Spring 2014 Pages: 42 + 9
appendices

This thesis was done for Oulu University of Applied Sciences Sula project. In the thesis electricity consumption of a garage was examined using classic time series analysis and search for correlation between power consumption and difference between outside and inside temperatures. Also, forecasts were made for power consumption and thermal conductance by applying linear regression. In thesis's context thermal conductance was defined as power consumption needed to increase the temperature difference between inside and outside air by one Celsius centigrade.

The purpose was to find a programmable way to detect a broken heating device from increased electricity consumption. The program should be able to run automatically on the Sula server.

Using time series analysis, trend and irregular components were detected from the electricity consumption measurement. With coefficient of determination linear correlation between the energy consumption and temperature difference was proven.

Power consumption forecast had the difference between outside and inside temperature as the explanatory variable. The forecast was good at comparing the last measured power consumption with certain temperature difference to average power consumption with the same temperature difference. The forecast was slow in adjusting to different kind of power consumption when used devices were changed, because the forecast method requires high number of observations. If the used devices would always be the same then this forecast method would be suitable for the purpose.

Conductance forecasts were faster in adjusting when the used devices were changed, but it can also be a downside because if the forecast adjusts too fast, it's useless detecting increased consumption. The adjusting speed is determined by the number of observations used. With high number of observations the forecast doesn't adjust too fast and is more suitable for the purpose.

Keywords: Energy, consumption, conductance, temperature

SISÄLLYS

TIIVISTELMÄ	3
ABSTRACT	4
SISÄLLYS	5
1 JOHDANTO	7
2 MITTAUSKOHDDE	8
2.1 Lämmityslaitteisto	8
2.2 Mittaukset	8
2.3 Mittauksiin vaikuttavat ulkoiset häiriöt	9
3 KÄYTETYT MENETELMÄT	11
3.1 Aikasarja-analyysi	11
3.2 Pearsonin korrelaatiokerroin	12
3.3 Selityskerroin	13
3.4 Autokorrelaatio	14
3.5 Hypoteesien testaus	14
3.6 Normaalijakauma	15
3.7 Studentin t-jakauma	15
3.8 Lineaarinen regressioanalyysi	15
3.9 Ennusteväli	17
3.10 Ennustetarkkuus	18
3.11 Lämpökonduktanssi	19
4 MITTAUSDATAN ANALYSOINTI	20
4.1 Sähkönkulutuksen riippuvuus lämpötilaerosta	21
4.2 Aikasarjan komponentit	25
4.2.1 Trendi	25
4.2.2 Kausivaihtelu	26
4.2.3 Satunnaisvaihtelu	29
5 ENNUSTEET	30
5.1 Teho	30
5.1.1 Otantamäärä	30
5.1.2 Ennustetulokset	32
5.2 Lämpökonduktanssi	34

5.3 Ennustetarkkuudet	36
5.4 Ennusteiden toteutus	37
5.4.1 Teho	37
5.4.2 Lämpökonduktanssi	38
6 YHTEENVETO	39
LÄHTEET	40
LIITTEET	42

1 JOHDANTO

Opinnäytetyössä analysoidaan Haukiputaalla sijaitsevan autotallin talven 2014 sähkön- ja energiankulutusta sekä tehdään ennusteita lineaarisella regressioanalyysillä. Opinnäytetyö tehtiin Sula-hankkeelle. Tavoitteena on luoda sovellus jolla voidaan havaita mm. laitevika tai auki jäänyt ikkuna, joka näkyy kasvaneesta sähkönkulutuksesta.

Analysointi toteutettiin klassisella aikasarja-analyysillä sekä tarkastelemalla lämpötilaeron riippuvuutta sähkön- ja energiankulutukseen. Ennusteita tehtiin sähkönkulutukselle, jossa selittävänä muuttujana on lämpötilaero, sekä lämpökonduktanssille, jossa selittävänä muuttujana on aika. Saatuja ennustetuloksia vertailtiin ennustetarkkuusluvuilla ja silmäilemällä kuvaajia.

Oulun ammattikorkeakoulu on osallisena Sula-hankkeessa, jonka rahoittaa EU:n Interreg Pohjoinen periferia -ohjelma. Hanke keskittyy kehittämään energiataloudellista asumista. Hankkeessa mm. tarjotaan asunnon omistajalle sovelluspalvelu, jolla voidaan seurata ja säästää käytettyä energiankulutusta. (SuLA - Sustainable Living Assistant. 2012.)

2 MITTAUSKOHDE

Mittauskohde on pienehkö autotalli Haukiputaalla (kuva 1). Autotallin sähköä kuluttava laitteisto koostuu enimmäkseen lämmityslaitteistosta joiden energiankulutus etäluetaan ja talletetaan tietokantaan. Autotalli on umpinainen, joten tuotettu lämpö karkaa enimmäkseen johtumalla seinien, katon, lattian ja ovien läpi sekä mahdollisista tiivisteraoista.



KUVA 1. Mittauskohteena oleva autotalli

2.1 Lämmityslaitteisto

Lämmitys on toteutettu kolmella NOBÖ C4N10 1000W 400X675MM -sähköpatterilla, Mitsubishi Electric MSZ-FH25VE -ilmalämpöpumpulla ja kolmella Deviflex DTIP 18 1220W 68m -lattialämmityskaapelilla. Ilmalämpöpumpun lämmitysteho on 1–6,3 kW ja jäähdytysteho 0,8–3,5 kW. Lämmöntalteenotto on toteutettu Enervent Pingvin ECO EDE - ilmanvaihtokoneella. Jokaiselle laitteelle on oma termostaatti tai säätöpaneeli. Putkivalaisimia löytyy 6 x 2 kappaletta, jotka myös tuottavat hieman lämpöä.

2.2 Mittaukset

Kaikki autotallin mittaukset tulevat Saikotek-merkkiselle ohjelmoitavalle logiikalle, jossa olevalla 3G-modeemilla mittaustiedot lähetetään Saikotekin

palvelimelle Espooseen ja sieltä Sulan tietokantapalvelimelle, josta tiedot luetaan. Kohteesta on mitattu mitta-arvoja tietokantaan 2013 syyskuun alusta alkaen.


Ohjelmoitavalle logiikalle tulevia mittauksia ovat kaksi sisälämpötilamittausta, kokonaissähkönkulutusmittari, sekä lattialämmityksen, ilmalämpöpumpun ja ilmanvaihtokoneen sähkönkulutusmittaukset. Ulkolämpötilan mittaus haetaan tietokantaan Ilmatieteenlaitoksen Oulun Vihreäsaaren sääasemalta, joten ulkolämpötilan paikkansapitävyys voi heittää jonkin verran todellisesta, koska sääaseman ja autotallin etäisyys on n. 30 km.

Sisälämpötilan mittaukset tulevat ohjelmoitavalle logiikalle 1-wire-väylän kautta, kokonaissähkönkulutus Modbus-väylän kautta ja muut sähkönkulutusmittaukset luetaan s0-impulssituloina.

Kokonaissähkönkulutus luetaan Entes EPR-04S -mittarilla, lattialämmityksen kulutus Schellcount EEM34DLC-3x65A -mittarilla ja IV-koneen ja ilmalämpöpumpun kulutus Schellcount EEM12-32A -mittareilla.

2.3 Mittauksiin vaikuttavat ulkoiset häiriöt

Autotallissa käyvät henkilöt voivat aiheuttaa mitta-arvojen heittelyä normaaleista arvoista. Ilmalämpöpumppu sijaitsee ulko-oven yläpuolella (kuva 2), joten jos ovi jää raolleen ja kylmää ulkoilmaa pääsee ilmalämpöpumpun läheisyyteen, voi ilmapumppu aktivoitua päälle suurella teholla, koska ilmalämpöpumpun lämpötila-anturin lämpötila laskee alle asetusarvon. Tämä aiheuttaa sähkönkulutuksessa äkillisen piikin. Tallin oven läheisyydessä sijaitsee sisälämpötila-anturit, joten jos tallin ovet aukaistaan, sisälämpötilassa voi tulla hetkellinen putoama ilman että se näkyy huomattavasti sähkönkulutuksessa. Talliin ajettu kylmä auto voi aiheuttaa sisälämpötilassa pienen laskun ja aiheuttaa hetkellisesti suurempaa sähkönkulutusta lämmityslaitteistossa.



KUVA 2. Autotallin laitteistojen ja ovien sijainnit

3 KÄYTETYT MENETELMÄT

Tässä osiossa käydään läpi menetelmät, joiden avulla päätelmät on saatu analysointi- ja ennusteosioissa.

3.1 Aikasarja-analyysi

Aikasarjalla tarkoitetaan ajan suhteen olevia havaintoarvoja. Hyvä tapa aloittaa aikasarjan tutkiminen on piirtää siitä kuvaaja, jossa vaaka-akselilla on aika ja pystyakselilla saadut havaintoarvot. Yleisin tapa tähän on kuvata havaintoarvot pisteinä jotka yhdistetään suorilla viivoilla. (Holopainen – Pulkkinen 1995, 209.)

Aikasarja-analyysi koostuu komponenttien havainnoinnista aikasarjasta. Komponentteja ovat trendi (T), kausivaihtelu (S), suhdannevaihtelu (C) ja satunnaisvaihtelu (I). Näitä komponentteja voidaan havainnoida aikasarjan kuvaajasta silmäilemällä ja matemaattisin menetelmin. (Holopainen – Pulkkinen 1995, 211.)

Komponenteista muodostetaan malli, jonka avulla voidaan tehdä ennusteita tai tarkastella tarkemmin jotain tiettyä osaa komponenteista. Malleja ovat summa- (kaava 1) ja tulomalli (kaava 2). Kumpaa malleista käytetään, riippuu siitä, kummalla mallilla saadaan lähempänä alkuperäisiä arvoja vastaavat estimaatit. Tietty komponentti voidaan poistaa tunnistamalla se aikasarjasta jonka jälkeen komponentit arvo vähennetään tai jaetaan, riippuen mallista. Tietty komponentti voidaan poistaa myös muilla menetelmillä, esimerkiksi kausivaihtelu differoimalla. (Holopainen – Pulkkinen 1995, 214.)

Summamalli (Y): $Y = T + S + C + I$ KAAVA 1

Tulomalli (Y): $Y = T * S * C * I$ KAAVA 2

Trendi (T) tarkoittaa pitkän aikavälin laskevaa tai nousevaa havaintoarvojen kehityssuuntaa. Trendi voidaan havaita matemaattisilla menetelmillä mm. Pearsonin korrelaatiokertoimella tai liukuvalla keskiarvolla. Trendi voidaan poistaa mallista mm. poistamalla aikasarjan lineaarisen regressioanalyysin kaavan tulos mallista. (Holopainen – Pulkkinen 1995, 215.)

Kausivaihtelu (S) on jaksottaista ja suhteellisen säännöllistä heilahtelua trendistä tai yleiskeskisarvosta. Kausivaihtelun jakson (L) pituus on korkeintaan vuosi. Kausivaihtelua voidaan havainnoida mm. autokorrelaation avulla. Kausivaihtelua voi aiheuttaa esim. päivänpituus ulkolämpötilaan. Kausivaihtelu saadaan poistettua mallista mm. liukuvalla keskiarvolla, jolloin otetaan keskiarvon arvoksi aikasarjan jakson pituus L. (Holopainen – Pulkkinen 1995, 212, 222.)

Suhdannevaihtelu (C) on pitkän aikavälin heilahtelua trendistä tai yleiskeskisarvosta, jonka jakson pituus on yli vuosi. Suhdannevaihtelu voidaan tunnistaa aikasarjasta parhaiten poistamalla siitä ensin trendin ja kausivaihtelun komponentit. (Holopainen – Pulkkinen 1995, 228.)

Satunnaisvaihtelu (I) on epäsäännöllistä ja ennustamatonta vaihtelua aikasarjassa. Pelkkää satunnaisvaihtelua voidaan havainnoida poistamalla aikasarjasta ensin muut komponentit. (Holopainen – Pulkkinen 1995, 230.)

3.2 Pearsonin korrelaatiokerroin

Pearsonin korrelaatiokerroin (kaava 3) kuvaa kahden muuttujan välistä lineaarista riippuvuutta. Kerroin r voi olla välillä -1 – 1 . Kerroin 1 saadaan, kun hajontakuvion kaikki pisteet ovat samalla nousevalla suoralla, ja -1 , kun kaikki pisteet ovat samalla laskevalla suoralla. Mitä lähempänä kerroin on arvoa 1 tai -1 , sitä voimakkaampi lineaarinen riippuvuus muuttujien välillä on. Muuttujien välillä voidaan olettaa olevan lineaarinen yhteys, mikäli saatu kertoimen arvo on vähintään kriittinen arvo Pearsonin korrelaatiokerrointaulukossa. (Holopainen – Pulkkinen 1995, 156.)

$$r = \frac{1}{n-1} \sum \left(\frac{x_i - \bar{x}}{s_x} \right) \left(\frac{y_i - \bar{y}}{s_y} \right) \quad \text{KAAVA 3}$$

r = Pearsonin otoskorrelaatiokerroin

\bar{x} = muuttujan x keskiarvo

s_x = muuttujan x keskihajonta

\bar{y} = muuttujan y keskiarvo

s_y = muuttujan y keskihajonta

n = havaintoparien määrä

3.3 Selityskerroin

Selityskerroin (kaava 4) ilmaisee, kuinka monta prosenttia selittävällä muuttujalla x saadaan selitettyä muuttujaa y . Selityskerrointa voidaan hyödyntää tarkasteltaessa lineaarisen mallin hyvyttä. (Holopainen – Pulkkinen 1995, 186.)

$$R^2 = r^2 * 100 \% \quad \text{KAAVA 4}$$

R^2 = selityskerroin

r = Pearsonin korrelaatiokerroin

y -arvojen kokonaispoikkeama y -arvojen keskiarvosta koostuu mallin selittämästä poikkeamasta ja selittämättömästä poikkeamasta. Selityskerroin (kaava 5, 6, 7, ja 8) kertoo mallin selittämän vaihtelun neliösumman osuuden kokonaisvaihtelun neliösummasta. (Taalina 2012.)

$$r^2 = \frac{SST - SSE}{SST} = \frac{SSR}{SST} \quad \text{KAAVA 5}$$

r^2 = Pearsonin korrelaatiokertoimen neliö

SST = kokonaisneliösumma, y :n kokonaisvaihtelu (total sum of squares)

SSR = osuus y vaihtelusta jonka malli selittää (explained sum of squares)

SSE = jäännöseliösumma, y selittämätön osuus (residual sum of squares)

$$SST = \sum (y_i - \bar{y})^2 \quad \text{KAAVA 6}$$

$$SSR = \sum (\hat{y}_i - \bar{y})^2 \quad \text{KAAVA 7}$$

$$SSE = \sum \hat{e}_t^2 \quad \text{KAAVA 8}$$

y_i = y arvo hetkellä i

\bar{y} = y keskiarvo

\hat{y}_i = regressiosuoran antama y arvo

\hat{e}_t = jäännöstermi hetkellä t

3.4 Autokorrelaatio

Autokorrelaatio kuvaa, kuinka samankaltaisia aikasarjan arvot ovat verrattuna eri aikaeron arvoihin. Autokorrelaatiokerroin r_k (kaava 9) kuvaa aikasarjassa viiveellä k olevien arvojen samankaltaisuutta asteikolla 0–1. (Holopainen – Pulkkinen 1995, 234.)

$$r_k = \frac{\sum_{t=1}^{n-k} (y_t - \bar{y})(y_{t+k} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad \text{KAAVA 9}$$

r_k = autokorrelaatiokerroin

y_t = y havaintoarvo hetkellä t

\bar{y} = y keskiarvo

k = viive

n = otantamäärä

Havaintoarvojen välillä voidaan osoittaa olevan samankaltaisuutta, mikäli arvo ylittää raja-arvon $2 / \sqrt{n}$. (Holopainen – Pulkkinen 1995, 236.)

3.5 Hypoteesien testaus

Hypoteeseilla testataan tiettyjen olettamuksien tai väitteiden todenperäisyyttä todennäköisyyksien avulla. Testissä muodostetaan nollahypoteesi ja vastahypoteesi. Yleensä nollahypoteesi on muotoa ”ei eroa”, joka pyritään hylkäämään vastahypoteesilla ”on eroa”. (Tilastollisen hypoteesin testaus. 2013.)

Hypoteesin hylkäämiseen voi tehdä kahdenlaista virhettä: 1. tyypin virhe, jossa tosi nollahypoteesi hylätään, ja 2. tyypin virhe, jossa väärä hypoteesi jää hylkäämättä (Tilastollisen hypoteesin testaus. 2013.).

Ennen nollahypoteesin testaamista päätetään, kuinka suuri riski otetaan, että tehdään hylkäämisvirhe. Hylkäämisvirheen todennäköisyyttä sanotaan merkitsevyystasoksi. Käytetyimmät merkitsevyystasot ovat 5 %, 1 % ja 0,1 %. (Holopainen – Pulkkinen 1995, 91.)

Hypoteeseja voidaan testata mm. keskiarvotestillä ja Studentin t-testillä. Testin saatua arvoa verrataan sen merkitsevyystasoa vastaavaan arvoon, jolloin voidaan tehdä päätelmä hypoteesien paikkansapitävyydestä. Testi voi olla yksi- tai kaksisuuntainen. Yksisuuntaisessa testataan onko vastahypoteesi suurempi tai pienempi kuin nollahypoteesi. Kaksisuuntaisessa testataan molemmat (erisuuri). (Holopainen – Pulkkinen 1995, 91.)

3.6 Normaalijakauma

Normaalijakauma kuvaa muuttujan x arvojen jakautumista tietyille arvoille tietyllä todennäköisyydellä. Normaalijakauman parametreja ovat odotusarvo ja varianssi. Normaalijakauman kuvaajassa odotusarvon kohdalla on huippu, joka loivenee tietyllä jyrkkyydellä riippuen varianssin suuruudesta. (Holopainen – Pulkkinen 1995, 69.)

3.7 Studentin t-jakauma

Studentin t-jakauma on keskiarvojen tarkastelussa käytettävä todennäköisyysjakauma, kun otoskoko on pieni. t-testin soveltaminen perustuu t-jakaumaan. t-jakauma muistuttaa muodoltaan odotusarvolla 0 ja varianssilla 1 jakautunutta normaalijakaumaa, jolla on paksummat hännät. Otosmäärän kasvaessa se lähestyy kyseistä normaalijakaumaa. (Studentin t-jakauma. 2014.)

3.8 Lineaarinen regressioanalyysi

Lineaarisisessa regressioanalyysissä havainnoidaan yhden selittävän muuttujan (x) lineaarista riippuvuutta selitettävään muuttujaan (y). Tarkoituksena on löytää muuttujien välinen yhteys ja kuvata sitä regressiosuoran (kaava 10) avulla. (Holopainen – Pulkkinen 1995, 173.)

$$y = b_1 + b_2x$$

KAAVA 10

y = regressiosuora

b₁ = vakiotermi

b₂ = kulmakerroin

Vakiotermi on arvo, jonka y saa, kun x on nolla eli regressiosuoran ja y-akselin leikkauspiste. Kulmakerroin kertoo, kuinka paljon ja mihin suuntaan y:n arvo muuttuu, kun x kasvaa yhden arvon verran. (Holopainen – Pulkkinen 1995, 174.)

Regressiosuoran kertoimet estimoidaan pienimmän neliösumman menetelmällä siten, että havaittujen arvojen ja mallin antamien arvojen erotuksista laskettujen virheneliösumma saa pienimmän mahdollisen arvon (kaava 11) (Lineaarinen regressioanalyysi. 2014.).

$$S = \sum_{i=1}^N (y_i - \beta_1 - \beta_2 x_i)^2 \quad \text{KAAVA 11}$$

S = virheneliösumma

y_i = y havaintoarvo

x_i = x havaintoarvo

β_1, β_2 = parametrit

n = havaintoparien määrä (x_i, y_i)

Derivoimalla edellisestä kaavasta saadaan estimaatit parametreille (kaava 12 ja 13) (Puumalainen 2011, 17.).

$$b_2 = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2} \quad \text{KAAVA 12}$$

$$b_1 = \bar{y} - b_2 \bar{x} \quad \text{KAAVA 13}$$

\bar{x} = x havaintoarvojen keskiarvo

\bar{y} = y havaintoarvojen keskiarvo

Parametrien keskivirheet (kaava 14 ja 15) kuvaavat, miten paljon eri otoksista estimoidut parametrit eroavat toisistaan. Jakamalla parametrin arvo keskivirheellä saadaan parametrin t-arvo, jonka avulla testataan hypoteesia, kun parametrin arvo on nolla. Saatua t-arvoa voidaan verrata Studentin t-jakaumataulukon arvoon vapausasteella $n - K$, jossa n on havaintojen määrä ja K estimoitavien parametrien määrä. Mikäli saatu t-arvo on suurempi kuin taulukon raja-arvo, nollahypoteesi hylätään. (Puumalainen 2011, 30.)

$$se(b_1) = \hat{\sigma} \sqrt{\frac{\sum x_i^2}{n \sum (x_i - \bar{x})^2}} \quad \text{KAAVA 14}$$

$$se(b_2) = \frac{\hat{\sigma}}{\sqrt{\sum (x_i - \bar{x})^2}} \quad \text{KAAVA 15}$$

$se(b_1)$ = b_1 parametrin keskivirhe

$se(b_2)$ = b_2 parametrin keskivirhe

$\hat{\sigma}$ = jäännöstermin keskivirhe

$$\hat{\sigma} = \sqrt{\frac{\sum y_i^2 - b_1 \sum y_i - b_2 \sum x_i y_i}{n-2}} \quad \text{KAAVA 16}$$

$$\hat{e}_i = y_i - b_1 - b_2 x_i \quad \text{KAAVA 17}$$

\hat{e}_i = jäännöstermi

y_i = y arvo hetkellä i

x_i = x arvo hetkellä i

b_1 = vakiotermi

b_2 = kulmakerroin

Jäännöstermi (kaava 17) kertoo paljonko toteutuneet arvo eroavat mallin antamista arvoista.

3.9 Ennusteväli

Ennusteväli (kaava 18) tarkoittaa väliä, mille ennustettava havaintoarvo tulee tietyllä todennäköisyydellä pääteltynä jo tulleista arvoista. Ennusteväliä käytetään antamaan ennusteen raja-arvot mm. regressioanalyysille. (Holopainen – Pulkkinen 1995, 196.)

$$\widehat{y}^* \pm t_{\alpha/2} s_e \sqrt{1 + \frac{1}{n} + \frac{(x^* - \bar{x})^2}{\sum (x_i - \bar{x})^2}}$$

KAAVA 18

$$s_e = \sqrt{\frac{\sum (y_i - \widehat{y}_i)^2}{n-2}}$$

KAAVA 19

\widehat{y}^* = ennusteen arvo

\widehat{y}_i = trendin arvo

t = t-jakauman kriittinen arvo

s_e = otoskeskihajonta

n = havaintoparien määrä

y_i = y havaintoarvo

x_i = x havaintoarvo

x^* = ennustettavan x:n arvo

\bar{x} = x arvojen keskiarvo

Ennustevälin todennäköisyyden määrittää Studentin t-jakauman kriittinen arvo joka valitaan t-jakaumataulukosta halutun todennäköisyyden perusteella, esim. 95 %:n todennäköisyyttä vastaa arvo 1,96. Ennustevälin todennäköisyydeksi valitaan yleensä 90–99 %. Mitä isompi todennäköisyys on, sitä isompi kerroin on ja raja-arvojen väli tulee suuremmaksi.

3.10 Ennustetarkkuus

Ennustearvojen hyvyttä voidaan tarkastella mm. itseisarvon keskivirheellä (MAD, mean absolute deviation) (kaava 20) ja sen suhteutetulla versiolla (MAPE, mean absolute percentage error) (kaava 21) (Perälampi 2012). Näissä menetelmissä verrataan ennustetta toteutuneeseen arvoon suhteutettuna otoskokoon, joten mitä lähempänä saatu arvo on nollaa, sitä parempi. Negatiiviset ennustetarkkuuden luvut kertovat, että ennuste on toteutuneeseen arvoon keskimääräisesti liian suuri. Positiiviset luvut kertovat ennusteen olleen keskimäärin liian pieni verrattuna toteutuneisiin arvoihin.

$$MAD = \frac{\sum_{i=1}^n (toteuma_i - ennuste_i)}{n}$$

KAAVA 20

$$MAPE = \frac{\sum_{i=1}^n \left(\frac{toteuma_i - ennuste_i}{toteuma_i} \right)}{n} * 100 \quad KAAVA 21$$

3.11 Lämpökonduktanssi

Lämpökonduktanssi (kaava 22) tarkoittaa tehoa, joka tarvitaan synnyttämään yhden celsiusasteen lämpötilaero lämpöeristeen yli (Krankkala 2013).

$$G = \frac{\varnothing}{\Delta T} \quad KAAVA 22$$

G = konduktanssi (W/°C)


\varnothing = teho (W)

ΔT = lämpötilaero (°C)

4 MITTAUSDATAN ANALYSOINTI

Sähkönkulutus mukautuu enimmäkseen sen mukaan, mitä lämmityslaitteita on päällä, koska sähköä kuluttava laitteisto koostuu suurimmilta osin lämmityslaitteistosta. Yksittäisten lämmityslaitteiden kulutus on riippuvainen muiden lämmityslaitteiden termostaattien säädöistä, jolloin eri lämmityslaittekokonaisuuksien määrä on $2^4 = 16$ kpl (on/off). Täten tarkastellaan kokonaissähkönkulutusta.

Kuvan 3 kuvaaja on mitatun kohteen kokonaissähkönkulutuksesta ja lämpötilaerosta. Kuvaajasta huomataan, että kokonaissähkönkulutus näyttää mukautuvan paljolti ulko- ja sisälämpötilan eron eli lämpötilaeron mukaan.




*KUVA 3. Sähkönkulutuksen ja lämpötilaeron tunnittasia mitta-arvoja
16.10.2013–4.1.2014*

4.1 Sähkönkulutuksen riippuvuus lämpötilaerosta

Mikäli sähkönkulutuksen ja lämpötilaeron välillä on lineaarinen riippuvuus, voidaan sen voimakkuus testata selityskertoimen avulla (kaava 4, 5).


Tunnittaiset mitta-arvot ovat saatu automaattisesti päivittyvältä Sulan nettihakemistolta ja energiankulutukset on laskettu tietokannan mittareiden kertyvästä kWh-lukemasta päivän, viikon ja kuukauden ajoilta.

Sähkönkulutuksen ja lämpötilaeron hajontakuviosta (kuva 4) nähdään viitteitä muuttujien lineaarisesta riippuvuudesta, mutta sähkönkulutuksessa on havaittavissa tasaantumista, kun lämpötilaero on noin alle 15 °C. Kyseiset arvot vääristävät trendiä liian loivaksi. Mikäli tarkoitus on saada isoja lämpötilaeroja myötäilevä trendi, tulisi alle 15 °C:n havaintoparit rajata pois mittadatasta.




KUVA 4. Autotallin kokonaissähkönkulutuksen ja lämpötilaeron hajontakuviotunnittaisista mitta-arvoista

Rajatuilla arvoilla trendi mukautuu paremmin aineistoon ja selityskerroin nousee 38,63 %:sta 51,5 %:iin (kuva 5) eli tuntidatalla voidaan sähkönkulutuksesta 51,5 % selittää johtuvan lämpötilaerosta. Tulee kuitenkin ottaa huomioon, että tuntidatassa on satunnaisuutta ja yksittäisiä piikkejä, jotka vaikuttavat saatuun selityskertoimeen.




KUVA 5. Autotallin lämpötilaeron ja sähkönkulutuksen hajontakuvio rajatuilla arvoilla

Päivittäisellä datalla on havaittavissa energiankulutuksen tasaantumista noin alle 15 °C lämpötilaerolla, joten rajataan havaintoparit arvoihin, joissa lämpötilaero on suurempi kuin 15 °C (kuva 6).




KUVA 6. Päivittäisen energiankulutuksen ja lämpötilaeron keskiarvojen hajontakuvi kaikilla arvoilla

Päivittäisen energiankulutuksen hajontakuvion pistejoukko on hajanaisempi kuin tuntidatalla, mutta jonkinasteista lineaarista riippuvuutta on havaittavissa (kuva 7). Selityskertoimeksi saadaan 57,7 %.




KUVA 7. Päivittäisen energiankulutuksen ja lämpötilaeron keskiarvojen hajontakuvi yli 15°C lämpötilaerolla

Viikoittaisesta hajontakuviosta (kuva 8) uupuu mitta-arvoja isommilla lämpötilaeroilla ja pistejoukossa on havaittavissa hajontaa samoilla lämpötilaeroilla. Selityskertoimeksi saadaan 50,69 %.



KUVA 8. Viikoittaiset energiakulutukset ja lämpötilaeron keskiarvojen hajontakuvio (>15 °C)

Kuukausikulutuksella (kuva 9) selityskertoimeksi saadaan 89,57 %, mutta tulee ottaa huomioon, että havaintoparien määrä on pieni.



KUVA 9. Kuukausittaisen energiankulutuksen ja lämpötilaeron keskiarvojen hajontakuvio

Korkeahko lämpötilaeron selityskerroin johtuu siitä, että suurin osa kulutuksesta tulee lämmityslaitteistosta. 2.9.2013–29.1.2014 ilmalämpöpumppu, IV-kone ja lattialämmitys ovat kuluttaneet 69,17 % kokonaiskulutuksesta (taulukko 1). Kyseisellä ajalla myös sähköpatterit ovat olleet välillä päällä. Tälle ei ole erillistä mittaria, joten lämmityslaitteiden kulutuksen osuus on todellisuudessa vielä suurempi.


TAULUKKO 1. Energiankulutukset 2.9.2013–29.1.2014.

2.9.2013 - 29.1.2014 Energiankulutukset		
Kokonaiskulutus	1344,951 kWh	
Lattialämmitys	33,983 kWh	2,53 %
Ilmalämpöpumppu	861,5165 kWh	64,06 %
IV-kone	34,696 kWh	2,58 %
Muut (sähköpatterit, lamput, plc, mittarit)	414,7555 kWh	30,84 %

4.2 Aikasarjan komponentit


4.2.1 Trendi

Koska sähkönkulutus mukautuu enimmäkseen lämpötilaeron mukaan, on sähkönkulutuksen trendi lämpötilaeron trendiin sidonnainen (kuva 10).



KUVA 10. Kokonaissähkönkulutuksen ja lämpötilaeron melkein identtiset trendit aikasarjassa

Täten aikasarjan trendin suunta ja jyrkkyys riippuu käytettävän aikavälin suuruudesta. Esimerkiksi otettaessa trendi isosta määrästä alkutalven arvoista tyypillisenä talvena trendi tulisi loivasti nousevaksi, koska kuukauden ulkolämpötilat laskevat tyypillisesti tammikuuhun asti, jonka jälkeen ne lauhtuvat (kuva 11). Pienellä aikavälillä lämpötilojen heittelyä voi tulla paljon, jolloin trendin jyrkkyys ja suunta voivat vaihdella paljon.




KUVA 11. Oulun sääaseman kuukausien lämpötilojen keskiarvot viimeiseltä 30 vuodelta (Pohjois-Pohjanmaan länsiosa – Perämeren vaikutuspiirissä. 2013.)

4.2.2 Kausivaihtelu


Kohteessa ei ole näy selvää kausivaihtelua silmäilemällä aikasarjan kuvaajaa (kuva 3), joten havainnoidaan kausivaihtelun olemassaoloa autokorrelaation avulla (kaava 9).

Autokorrelaation kuvaaja (kuva 12) tehtiin R-tilasto-ohjelmalla alku- ja keskitalven 2000 tuntidatan arvosta (83 päivää) viiveillä 0–33. Kuvaajasta nähdään, että kaikki arvot ovat kriittisen rajan ylittäviä ja laskevia viiveen kasvaessa. Tämä tarkoittaa, että kaikki arvot viiveillä 1–33 ovat samankaltaisia, mutta samankaltaisuutta on enemmän pienillä viiveillä. Tasaisesti laskevat arvot viiveen suhteen viittaavat datassa olevan trendi ja satunnaisuutta. (Holopainen – Pulkkinen 1995, 235.) Tuntidatalla ei ole huomattavissa selvää kausivaihtelua.




KUVA 12. Kokonaissähkönkulutuksen autokorrelaatio tuntidatalla (2000 arvoa)

Päivittäisen energiankulutuksen autokorrelaation kuvaajassa (kuva 13) on huomattavissa aaltomaisuutta, mutta arvot jäävät alle kriittisen rajan, paitsi viiveellä 1 ja 20. Viiveellä 1 samankaltaisuutta on odotettavissa, koska lämpötilaeroa kahden päivän ajalla ei yleensä tule paljoa, joten kulutus pysyy lähes samankaltaisena.



KUVA 13. Autotallin päivittäisen energiakulutuksen autokorrelaatio (149 arvoa)

Viiveellä 20 on negatiivinen korrelaatio eli 20 päivän välein arvojen erilaisuus kasvaa. Päivittäisen energiankulutuksen kuvaajasta (kuva 14) ei ole nähtävissä selvää 20 päivän välein tapahtuvaa kasvavaa erilaisuutta, vaan energiankulutus mukautuu enimmäkseen lämpötilaeron mukaan.



KUVA 14. Päivittäinen energiankulutus 2.9.2013–27.1.2014

Kausivaihtelua voi tulevaisuudessa aiheuttaa päivänpituus, jolloin päivän ja yön lämpötilaeron vaihtelu kasvaa. Alku- ja keskitalvella päivänpituus on lyhyt ja aurinko ei lämmitä paljoa, joten sen vaikutusta ei ole nähtävissä tarkastelluissa arvoissa. Mittausdatassa ei silmäilemällä eikä autokorrelaation avulla näy selvää kausivaihtelua.

4.2.3 Satunnaisvaihtelu

Tuntidatassa on huomattavissa selvää satunnaisuutta (kuva 3). Satunnaisuutta aiheuttaa mm. lämmityslaitteiden on/off-toimintatapa, jolloin lämmityslaitte kytkeytyy päälle, kun termostaattiin asettama lämpötilaraja alittuu, ja poistuu päältä, kun lämpötilaraja on saavutettu (siksak-kuvio). Lämmitystarve myös vaihtelee, joten lämmityslaitteiden toimintatavasta johtuva siksak-kuvio ei ole säännöllistä. Ihmisten aiheuttamat ulkoiset häiriöt sekä eri lämmityslaittekokonaisuudet aiheuttavat kokonaissähkönkulutuksessa myös vaihtelevaa satunnaisuuden suuruutta.

5 ENNUSTEET

Tässä osiossa käsitellään ennustemalleissa huomioitavia asioita, kuten havaintoarvojen määrä, sekä analysoidaan ja vertaillaan saatuja ennustetuloksia. Ennusteet tehtiin tunnittaiselle tehonkulutukselle, jossa selittävänä muuttujana oli lämpötilaero, sekä tunnittaiselle lämpökonduktanssille, jossa selittävänä muuttujana oli aika. Kummatkin ennusteet tehtiin lineaarisella regressioanalyysillä (kaava 8) käyttäen 95 %:n ennusteväliä (kaava 16).

5.1 Teho

5.1.1 Otantamäärä

Ennen kuin ennusteita tehdään, tulisi ottaa selvää, mikä on sopiva määrä käytettäville havaintoarvoille. Käytetään havaintoarvojen lukumäärän arviointiin lineaarisessa regressioanalyysissä lämpötilaerolla selityskerrointa, p-arvoa ja saatujen regressiosuoran kertoimien t-arvoja. Tuntidatalla hajontakuvion pistejoukko myötäilee melko hyvin trendiä, kun selityskerroin on n. 50 % (kuva 5), joten valitaan se häilyväksi raja-arvoksi. Kertoimien t-arvo saadaan jakamalla kertoimen arvo sen keskivirheellä (kaava 14 ja 15). Saatu t-arvo noudattaa tällöin Studentin t-jakaumaa, joten sitä voidaan käyttää testimuuttujana. p-arvo kertoo todennäköisyyden, jolla yhtä merkittävä ero tuloksessa saadaan käyttämällä nollahypoteesia eli todennäköisyys, jolla saman tuloksen voi saada sattumalta. Riittävänä t-arvona pidetään yleisesti vähintään 2 ja p-arvoa alle 0,05 joka vastaa 5 %:n todennäköisyyttä hylkäämisvirheeseen. (Holopainen – Pulkkinen, 177, 187-188.)

Saadut tulokset on laskettu R-tilasto-ohjelmalla. Otannat on otettu 2380 tuntidatan (n. 3,3 kk) mitta-arvosta, jotka on rajattu $>15^{\circ}\text{C}$:n havaintopareihin. Havaintoparien lukumääriä ovat 50, 100, 200, 300, 500 ja 1000, joista jokaista on otettu viisi kappaletta. Otannoissa ei käytetä samoja mitta-arvoja, paitsi isoilla havaintoparien määrillä 500 ja 1000. Mitä isommalta aikaväliltä mitta-arvoja otetaan, sitä enempi mittadata sisältää lämpötilaeron vaihtelua ja saadaan paremmin kuvaava regressiosuora. Kyseisillä otantamäärillä

Pearsonin korrelaatiokertoimien kriittisten rajojen arvot vastaavat selityskertoimena enintään 7,78 %:n selityskerrointa, joten käytettävä selityskerroin on reilusti yläkanttiin, jolloin muuttujien välillä tulisi olla selvää lineaarista riippuvuutta.

Saaduista arvoista (taulukko 2) nähdään, että hyvyysluvut voivat jäädä huonoiksi jopa isolla määrällä havaintopareja. Taulukkoon punaisella merkityt ovat riittämättömiä hyvyyslukuja ja vihreät riittäviä. Ennusteita tehdessä olisi suositeltavaa käyttää vähintään 1000 havaintoparia, jotta saadaan tarpeelliset hyvyysluvut.


TAULUKKO 2. Hyvyysluvut lineaarisella regressioanalyysillä lämpötilaerolla.

Otoksien määrä	Vakiotermin arvo	Vakiot. keskivirhe	Vakiot. t-arvo	Kulmakertoimen arvo	Kk keskivirhe	Kk t-arvo	R ²	p-arvo
1. 50kpl	-2911,4	1100	-2,647	220,1	60,7	3,626	0,215	0,000695
2. 50kpl	1034,285	181,654	5,694	2,431	7,532	0,323	0,002166	0,7483
3. 50kpl	592,081	54,347	10,89	17,428	2,144	8,13	0,5793	0,034572
4. 50kpl	-62,31	506,97	-0,123	31,12	23,86	1,305	0,03424	0,1983
5. 50kpl	-542,618	101,799	-5,33	41,743	4,721	8,841	0,6195	0,11634
1. 100kpl	350,14	372,06	0,941	34,44	17,44	1,975	0,03827	0,05111
2. 100kpl	-919,777	208,087	-4,42	74,635	8,896	8,39	0,418	4,05E-08
3. 100kpl	-386,394	68,967	-5,603	34,233	3,386	10,109	0,5105	3,32E-06
4. 100kpl	-73,023	64,594	-1,13	18,172	3,655	4,971	0,2014	0,001951
5. 100kpl	-291,94	226,36	-1,29	28,35	11,33	2,503	0,06008	0,01398
1. 200kpl	273,58	239,84	1,141	30,32	10,71	2,83	0,03887	0,005138
2. 200kpl	-247,105	39,533	-6,251	27,677	2,073	13,348	0,4736	3,32E-06
3. 200kpl	-707,589	135,475	-5,223	49,468	6,673	7,413	0,2172	2,74E-07
4. 200kpl	-549,696	56,592	-9,713	46,565	2,868	16,234	0,571	3,32E-06
5. 200kpl	-214,134	62,321	-3,436	32,376	3,098	10,452	0,3556	3,32E-06
1. 300kpl	-454,622	194,148	-2,342	55,185	8,933	6,178	0,1135	0,001099
2. 300kpl	-235,861	60,206	-3,918	26,566	3,093	8,588	0,1984	6,51E-12
3. 300kpl	-605,468	39,643	-15,27	49,218	1,953	25,2	0,6807	3,32E-06
4. 300kpl	-421,077	68,21	-6,173	45,245	3,429	13,193	0,3687	3,32E-06
5. 300kpl	-422,68	36,36	-11,62	43,03	1,62	26,55	0,7029	3,32E-06
1. 500kpl	-958,408	127,618	-7,51	73,562	6,185	11,89	0,2212	3,32E-06
2. 500kpl	-364,576	45,735	-7,972	37,408	2,279	16,412	0,351	3,32E-06
3. 500kpl	-419,028	35,695	-11,74	43,654	1,648	26,49	0,5848	3,32E-06
4. 500kpl	-168,83	25,864	-6,528	23,67	1,323	17,895	0,3914	3,32E-06
5. 500kpl	-531,847	81,446	-6,53	44,096	2,878	15,32	0,3203	3,32E-06
1. 1000kpl	-479,529	31,352	-15,29	42,528	1,325	32,09	0,5078	3,32E-06
2. 1000kpl	-805,21	76,11	-10,58	62,82	3,74	16,8	0,2204	3,32E-06
3. 1000kpl	-496,433	29,879	-16,61	44,867	1,428	31,41	0,4972	3,32E-06
4. 1000kpl	-528,988	23,893	-22,14	47,734	1,199	39,82	0,6137	3,32E-06
5. 1000kpl	-431,656	24,402	-17,69	40,888	1,137	35,96	0,5644	3,32E-06

5.1.2 Ennustetulokset


Ennusteet tehtiin siten, että verrataan uusimman havaintoparin lämpötilaeron sähkönkulutusta edeltävistä arvoista tehdyn regressiosuoran antamaan sähkönkulutuksen arvoon, jossa käytetään uusimman arvon lämpötilaeroa. Tällöin verrataan uusimman lämpötilaeron sähkönkulutuksen arvoa edellisten arvojen saman lämpötilaeron keskimääräiseen arvoon. Ennusteet tehtiin yksi tunti eteenpäin tuhannella otannalla 18.3. alkaen.

Ennen ennusteiden aloittamista kohteessa oli ollut päällä enimmäkseen IV-kone ja ilmalämpöpumppu, joten suurin osa otantamäärän arvoista tulee näistä arvoista. Aikavälillä 16.3.–24.3. on ollut päällä sähköpatterit, jotka kuluttavat ilmalämpöpumppua reilusti enemmän sähköä (kuva 15).




KUVA 15. Kohonnut sähkönkulutus sähköpattereista (W per tunti)

Sähköpattereiden suuremmasta kulutuksesta johtuu 16.3.–24.3. ennusteen liian pieni arvo verrattuna toteutuneeseen (kuva 16). Tuhannella otantamäärällä (n. 42 päivää) kohonneeseen sähkönkulutukseen reagointi vie todella kauan aikaa. Aikavälillä 24.3.–29.3. lattialämmitys (kuva 16) on ollut päällä, jonka sähkönkulutus tekee siksak-kuviota isolla vaihteluvälillä. 1.4. alkaen kohteessa on ollut ilmalämpöpumppu ja IV-kone päällä, jolloin toteutuneet arvot pysyvät raja-arvojen sisällä yhtä piikkiä lukuunottamatta.



Kuva 16. Ennustetulokset lineaarisella regressioanalyysillä, jossa lämpötilaero selittävänä muuttujana aikaväliltä 18.3.–9.4.

Käyttäessä kuuden toteutuneen arvon keskiarvoja nähdään lattialämmityksen keskimääräinen kulutus selvemmin verrattuna ennusteeseen ja ylärajaan (kuva 17).



KUVA 17. Lämpötilaeron ennusteet ja kuuden toteutuneen arvon keskiarvot


Ennustetavan hyvä puoli on vertaus edellisten arvojen saman lämpötilaeron sähkönkulutukseen ja huono puoli on hidas sopeutuminen sähkönkulutuksen muutoksiin käytettäessä suurta otoskokoa. Pienellä otoskoolla lämpötilaeron vaihtelua ei tule paljoa, jolloin regressiosuora voi olla vääristynyt ja hyvyysluvut

jäävät usein riittämättömiksi. Ennustemenetelmä ei tule toimimaan kohteessa, jossa on lämpötilaerosta riippumatonta vaihtelua, koska tällöin sähkönkulutus tietylle lämpötilaerolle on isolla vaihteluvälillä, jolloin lineaarista riippuvuutta muuttujien välille ei tule.

5.2 Lämpökonduktanssi


Lineaarisen regressioanalyysin lämpökonduktanssin ennusteilla nähdään, kasvaako käytetty teho yhtä lämpötilaeron celsiusta kohden verrattuna tietyn aikavälin regressiosuoran ennusteen arvoon. Tällä ennustetavalla ei ole järkevää tarkastella hyvyyslukuja otantamääriä testattaessa, koska selittävä muuttuja on aika, joten ennusteiden otantamäärät joudutaan kokeilemaan. Ennusteet tehtiin 72, 168 ja 336 tuntidatan otantamäärällä yksi tunti eteenpäin 25.3. alkaen. Otantamäärät vastaavat kolmen, seitsemän ja 14 päivän dataa.

Ennen ennusteiden aloittamista kohteeseen oli laitettu 24.3. päälle lattialämmitys, joka aiheuttaa lämpökonduktanssissa siksak-kuviolla isolla vaihteluvälillä (kuva 18). Ennen kuin lattialämmitys on ollut päällä, lämpökonduktanssi on ollut tasaista. Tämä lisää ennustevälin raja-arvojen välin määrää, koska keskihajonta on kasvanut edellisiin arvoihin verrattaessa. Suurilla otantamäärillä tähän sopeutuminen vie kauemmin aikaa, koska suurin osa havaintoarvoista on ajalta, jolloin hajonta on ollut pientä.




KUVA 18. Lämpökonduktanssin muutokset ennen ennusteiden tekemistä


Ennusteista nähdään, että kolmen päivän otantamäärällä raja-arvot reagoivat nopeiten hajonnan muutoksiin (kuva 19). Kun hajonta on suurta, raja-arvot reagoivat nopeasti todella suurelle välille, ja kun hajonta pienenee, raja-arvot supistuvat todella pienelle välille. Seitsemän ja neljäntoista päivän otoskoolla tämä tapahtuu paljon hitaammin. Kuvaajissa oleva suora viiva johtuu yhteyden katkosta.



KUVA 19. Kolmen päivän otantamäärän ennusteet



KUVA 20. Seitsemän päivän otantamäärän ennusteet



KUVA 21. Neljäntoista päivän otantamäärän ennusteet

Ennustetavan hyvä puoli on nopeahko sopeutuminen erilaisiin muutoksiin riippuen käytetystä otantamäärästä. Tämä voi olla myös huono puoli, koska ennuste voi sopeutua liian nopeaa vioittuneen laitteen kasvaneeseen sähkönkulutukseen. Toinen huono puoli on jos sähkönkulutus kasvaa pikkuhiljaa, ennuste sopeutuu siihen.

5.3 Ennustetarkkuudet

Ennustetarkkuuksien arvot otettiin samalta ajankohdalta 25.3.–8.4. Eroava ennusteiden lukumäärä (taulukko 3) tulee katkoista datassa ja eroavasta skriptin toimintatavasta.

TAULUKKO 3. Ennustetarkkuudet.

Ennuste	Ennusteen otoskoko	Ennusteiden määrä	MAD	MAPE
Lin.reg.analyysi lämpökond.	72	187	1,349	0,024
Lin.reg.analyysi lämpökond.	168	187	3,725	0,067
Lin.reg.analyysi lämpökond.	336	187	-0,944	-0,02
Lin.reg.analyysi lämpötilaero	1000	180	9,813	0,01

Lämpökonduktanssilla ennuste tehdään aina tunti eteenpäin seuraavalle tunnille, joka liitetään toteutuneeseen arvoon seuraavalla syklillä.

Lämpötilaerolla verrataan uusimman lämpötilaeron sähkönkulutuksen arvoa regressiosuoran antamaan tulokseen kyseisellä lämpötilaerolla. Lämpötilaeron toimintatavalla tulee useampi välistä jäänyt ennuste, jos datassa tulee katkoksia, koska arvoa verrataan aina vain viimeksi tulleetseen arvoon. Lämpökonduktanssin toimintatavalla välistä jää ennusteita, jos katkos kestää kauemmin kuin tunnin.

Ennustetarkkuuksien arvoista (taulukko 3) nähdään, että lähimpänä toteutunutta arvoa on lämpötilaeron ennusteet, koska sillä on pienin prosentuaalinen ennustevirheen arvo (MAPE). MAD-arvo kertoo, paljonko keskivirhe on käytetyllä yksiköllä. Lämpökonduktanssilla paras ennustetarkkuus saatiin kahden viikon otantamäärällä. Ennustetarkkuuden luvut eivät kerro, kuinka hyvin ennustetapa soveltuu havaitsemaan kasvaneen sähkönkulutuksen, vaan kuinka lähellä ennuste on toteutunutta arvoa.

5.4 Ennusteiden toteutus

Ennusteet suoritetaan Linux-virtuaalipalvelimella Bash-skriptinä (liitteet 2 ja 4) automaattisesti tunnin välein Cron-ajastuspalvelulla.

Kummallakin ennustetavalla skripti hakee ensiksi uusimmat mittatiedot SQL-tietokannasta suorittamalla Perl-skriptin ja tallettaa mittatiedot palvelimelle tekstitiedostoksi. Perl-skripti on jätetty pois liitteistä, koska se sisältää tietokannan käyttäjätunnuksen ja salasanan.

5.4.1 Teho

Saaduista mitta-arvoista rajataan Awk-työkalulla omaan tiedostoon uusimman tunnin mitta-arvot sekä uusimman tunnin jälkeiset tuhat arvoa. Tämän jälkeen suoritetaan R-skripti (liite 3). R-skripti lukee luodut tekstitiedostot omiin muuttujiin, tekee tuhannesta sähkönkulutuksen ja lämpötilaeron arvosta regressiosuoran, luo regressiosuoralla sähkönkulutuksen arvot viimeksi tulleen tunnin lämpötilaerolle ja tulostaa tiedot tekstitiedostoksi. R:n tekemä tekstitiedosto tehdään kertyväksi lokiksi. Saaduista arvoista tehdään graafi

Gnuplotilla (kuva 16) (liite 6), joka siirretään palvelimen nettihakemistoon ennusteiden helppoa seuranta varten.

5.4.2 Lämpökonduktanssi

Sähkönkulutuksen ja lämpötilojen mittatiedot lasketaan lämpökonduktanssiksi Awk-työkalulla ja rajataan 72, 168 ja 336 havaintoparin erillisiksi tekstitiedostoiksi, joissa on päivämäärä ja lämpökonduktanssi. Tämän jälkeen suoritetaan R-skripti (liite 5). R-skripti lukee tekstitiedostot omiin muuttujiin, tekee jokaiselle oman regressiosuoran, ennusteet ja raja-arvot seuraavalle arvolle sekä luo seuraavan tunnin ajan ja tulostaa tiedot tekstitiedostoksi. R:n tekemä ennusteen tekstitiedosto tehdään kertyväksi lokiksi.

Ennustetekstitiedosto liitetään päivämäärän mukaan tekstitiedostoon, jossa ovat toteutuneet arvot ja näistä tehdään oma tekstitiedosto. Saaduista arvoista tehdään Gnuplotilla graafit (kuva 18, liitteet 7, 8 ja 9), jotka siirretään palvelimen nettihakemistoon helppoa seuranta varten.

6 YHTEENVETO

Opinnäytetyön tavoitteena oli analysoida sähkönkulutuksen mittadataa ja löytää toteutustapa, jolla havaitaan normaalista kasvanut sähkönkulutus.

Klassisella aikasarja-analyysillä ja tarkastelemalla sähkönkulutuksen riippuvuutta lämpötilaerosta saatiin hyvä yleiskuva, kuinka kohteen sähkönkulutus käyttäytyy. Kohteen sähkönkulutus mukautuu talvisin enimmäkseen lämpötilaeron mukaan ja aikasarjan trendi on tähän sidonnainen. Satunnaisuutta aiheuttavat lämmityslaitteiden toimintatapa, ulkoiset häiriöt ja eri lämmityslaitetekonaisuudet.

Lineaarisella regressioanalyysillä, jossa selittävänä muuttujana oli lämpötilaero, saatiin hyviä vertauksia, kuinka suuri sähkönkulutuksen tulisi keskimäärin olla tietyllä lämpötilaerolla verrattuna edellisten arvojen sähkönkulutuksiin.

Ennustetavan heikko puoli oli kuitenkin hidas sopeutuminen lämmityslaitetekonaisuuksien muutoksiin isolla otoskoolla. Pienellä otoskoolla hyvyysluvut eivät olleet riittävät.

Lämpökonduktanssin ennusteilla lämmityslaitetekonaisuuksien muutoksiin reagointi oli huomattavasti nopeampaa kuin lämpötilaeron ennusteilla, koska otoskoko on pienempi. Pienellä otoskoolla ennuste kuitenkin sopeutuu liian nopeaa kasvaneeseen sähkönkulutukseen, jolloin ylärajan ylityksiä nousseesta sähkönkulutuksesta ei tule. Kaikissa otosko'oissa pätee, että jos sähkönkulutus nousee pikkuhiljaa, ennuste sopeutuu siihen.

Mikäli päällä olevat lämmityslaitteet ja termostaattien asetukset pysyisivät aina samoina, parhaiten tavoitteen toteuttaisi lämpötilaeron ennuste. Kuitenkin jos lämmityslaitetekonaisuuksia vaihdellaan, paras ennustemalli olisi kokeilluista lämpökonduktanssin ennusteet yhden tai kahden viikon otoskoolla.

LÄHTEET

Heinonen, Jarmo 2006. SPSS. Saatavissa:

<http://opko.laurea.fi/~jarhein/SPSS/SPSS.htm>. Hakupäivä 4.4.2014.

Holopainen, Martti – Pulkkinen, Pekka 1995. Tilastolliset menetelmät. Porvoo: WSOY.

Krankkala, Jussi-Pekka 2013. Energiankulutuksen jatkuvatoiminen seuranta pien- ja kerrostaloissa. Opinnäytetyö. Oulun ammattikorkeakoulu, talotekniikan koulutusohjelma. Saatavissa:

<https://publications.theseus.fi/handle/10024/62540>. Hakupäivä: 2.4.2014.

Lineaarinen regressioanalyysi. 2014. Wikipedia. Saatavissa:

http://fi.wikipedia.org/wiki/Lineaarinen_regressioanalyysi. Hakupäivä 4.4.2014.

Perälampi, Mika 2012. Tilausohjautuvan tuoteperheen ennusteprosessin kehittäminen. Opinnäytetyö. Metropolia ammattikorkeakoulu, tuotantotalouden koulutusohjelma. Saatavissa:

<https://publications.theseus.fi/handle/10024/47162> Hakupäivä: 2.4.2014.

Pienimmän neliösumman suora. 2014. Wikipedia. Saatavissa:

http://fi.wikipedia.org/wiki/Pienimm%C3%A4n_neli%C3%B6summan_suora. Hakupäivä 4.4.2014.

Pohjois-Pohjanmaan länsiosa – Perämeren vaikutuspiirissä. 2013. Ilmasto-opas. Saatavissa:

<https://ilmasto-opas.fi/fi/ilmastonmuutos/suomen-muuttuva-ilmasto/-/artikkeli/56585779-ca29-443b-824b-246be7e8ea93/pohjois-pohjanmaan-lansiosa-perameren-vaikutuspiirissa.html>. Hakupäivä 12.5.2014.

Puumalainen, Kaisu 2011. Kvantitatiiviset tutkimusmenetelmät. Saatavissa:

https://noppa.lut.fi/noppa/opintojakso/a130a0350/luennot/luento5_kalvot.pptx. Hakupäivä 9.4.2014.

Studentin t-jakauma. 2013. Wikipedia. Saatavissa:
http://fi.wikipedia.org/wiki/Studentin_t-jakauma. Hakupäivä 4.4.2014.

SuLA – Sustainable Living Assistant. 2012. Saatavissa:
<http://www.oamk.fi/hankkeet/sula/>. Hakupäivä 12.5.2014.

Taalina, Aki 2013. Lineaarinen malli. Saatavissa:
<http://tilastoapu.wordpress.com/2012/10/20/lineaarinen-malli/>. Hakupäivä
4.4.2014.

Tilastollisen hypoteesin testaus. 2013. Wikipedia. Saatavissa:
http://fi.wikipedia.org/wiki/Tilastollisen_hypoteesin_testaus. Hakupäivä
4.4.2014.

LIITTEET

Liite 1 Lähtötietomuistio

Liite 2 Tehon Bash-skripti

Liite 3 Tehon R-skripti

Liite 4 Lämpökonduktanssin Bash-skripti

Liite 5 Lämpökonduktanssin R-skripti

Liite 6 Tehon Gnuplot-skripti

Liite 7 Lämpökonduktanssin kolmen päivän otoskoon Gnuplot-skripti

Liite 8 Lämpökonduktanssin seitsemän päivän otoskoon Gnuplot-skripti

Liite 9 Lämpökonduktanssin 14 päivän otoskoon Gnuplot-skripti

LÄHTÖTIETOMUISTIO

Tekijä Mika Peltoperä, t9pemi00@students.oamk.fi

Tilaaja Sula-hanke

Tilaajan yhdyshenkilö ja yhteystiedot OAMK tekniikan yksikkö, tietotekniikkaosasto,
Teemu Korpela, tkorpela@oamk.fi

Työn nimi Lämmitysmenetelmien analysointi tilastomenetelmillä

Työn kuvaus Analysoidaan autotallin sähkönkulutusta klassisella aikasarja-analyysillä, tarkastellaan lämpötilaeron riippuvuutta sähkönkulutukseen, sekä tehdään ennusteita lineaarisella regressioanalyysillä.

Työn tavoitteet

Analysoida sähkönkulutusta ja löytää ohjelmallinen toteutus jolla voidaan havaita normaalista poikkeava sähkönkulutus.

Tavoiteaikataulu Kevät 2014

```
#!/bin/bash
```

```
# Mennään hakemistoon johon tehdään tiedostot  
cd /home/user/regana/
```

```
# Haetaan tietokannasta tiedot tekstitiedostoihin  
./hae_pirttikoski_energy.pl > pirttikoski_autotalli_energy.txt  
./hae_pirttikoski_indoor_temp.pl > pirttikoski_autotalli_indoor_temp.txt  
./hae_pirttikoski_outdoor_temp.pl > pirttikoski_autotalli_outdoor_temp.txt  
./hae_pirttikoski_laskurit.pl > pirttikoski_autotalli_counters.txt  
join -t" " -1 1 -2 1 pirttikoski_autotalli_indoor_temp.txt  
pirttikoski_autotalli_outdoor_temp.txt > apu.temp  
join -t" " -1 1 -2 1 apu.temp pirttikoski_autotalli_energy.txt > apu2.temp  
join -t" " -1 1 -2 1 apu2.temp pirttikoski_autotalli_counters.txt >  
pirttikoski_autotalli_kaikki_yhdessa.txt  
rm -f *temp
```

```
#Tehdään 1 ja 1k mitta-arvon tekstitiedostot R-skriptiä varten  
cat pirttikoski_autotalli_kaikki_yhdessa.txt | awk '{if($2-$3>14) print $1,$2-$3,$4}' | tail -1001 | head -1000 >kaikki1k.txt  
cat pirttikoski_autotalli_kaikki_yhdessa.txt | awk '{if($2-$3>14) print $1,$2-$3,$4}' | tail -1 >viimeisin.txt  
chmod 755 kaikki1k.txt  
chmod 755 viimeisin.txt
```

```
#Suoritetaan R-skripti joka luo tekstitiedoston  
./r_regana  
chmod 755 regana_viime.txt
```

```
#Siistitään r-skriptin luomaa tekstitiedostoa ja tehdään siitä kertyvä tiedosto  
tail -1 regana_viime.txt | awk '{print $2,$3,$4,$5,$6,$7}' >> regana_kertyva.txt  
chmod 755 regana_kertyva.txt
```

```
#Tehdään graafi  
gnuplot plot_regana
```

```
#Siirretään graafi ja tiedostot nettihakemistoon  
chmod 755 regana.png  
mv regana.png /var/www/sula/  
cp -a regana_kertyva.txt /var/www/sula/
```

```
#!/usr/bin/env Rscript

# Määritetään työhakemisto
setwd("/home/user/regana")

#Haetaan eri määrä mittausarvoja
arvot1k<-read.table("/home/user/regana/kaikki1k.txt")
viimeisin<-read.table("/home/user/regana/viimeisin.txt")

#Nimetään sarakkeet muuttujiin
pvm1k<-arvot1k[,1]
lampero1k<-arvot1k[,2]
kokkul1k<-arvot1k[,3]
arvot1k<-data.frame(pvm1k, lampero1k, kokkul1k)

pvmviim<-viimeisin[,1]
lamperoviim<-viimeisin[,2]
kokkulviim<-viimeisin[,3]
viimeisin<-data.frame(pvmviim, lamperoviim, kokkulviim)

#lineaarinen regressioanalyysi
lm.arvot1k<-lm(kokkul1k~lampero1k, arvot1k)

#Trendin, ylä- ja alarajan arvot 95% ennustevälillä
rajat1k<-predict(lm.arvot1k, newdata=data.frame(lampero1k=lamperoviim), in-
terval="prediction", level=0.95)

#rajat omiin muuttujiin
trendi<-rajat1k[1]
alaraja<-rajat1k[2]
ylaraja<-rajat1k[3]

#Pvm oikeaan muotoon
pvmviim<-as.POSIXct(pvmviim, format = "%Y-%m-%d-%H")
pvmviim<-format(pvmviim,"%Y-%m-%d-%H")

#Luodaan taulukko josta tekstitiedosto tehdään
taul<-cbind(pvmviim, lamperoviim, kokkulviim, trendi, alaraja, ylaraja)

#Tekstitiedosto viime tulleele arvolle, trendin arvolle ja luottamusväleille
write.table(taul, file="regana_viime.txt", quote=FALSE, sep=" ")
```

```
#!/bin/bash
```

```
# Mennään hakemistoon johon tehdään tiedostot  
cd /home/user/regana/
```

```
# Haetaan tietokannasta tiedot tekstitiedostoihin  
./hae_pirttikoski_energy.pl > pirttikoski_autotalli_energy.txt  
./hae_pirttikoski_indoor_temp.pl > pirttikoski_autotalli_indoor_temp.txt  
./hae_pirttikoski_outdoor_temp.pl > pirttikoski_autotalli_outdoor_temp.txt  
./hae_pirttikoski_laskurit.pl > pirttikoski_autotalli_counters.txt  
join -t" " -1 1 -2 1 pirttikoski_autotalli_indoor_temp.txt  
pirttikoski_autotalli_outdoor_temp.txt > apu.temp  
join -t" " -1 1 -2 1 apu.temp pirttikoski_autotalli_energy.txt > apu2.temp  
join -t" " -1 1 -2 1 apu2.temp pirttikoski_autotalli_counters.txt >  
pirttikoski_autotalli_kaikki_yhdessa.txt  
rm -f *temp
```

```
#Tehdään lämpökonduktanssille 3, 7 ja 14 pvä tiedostot  
tail -72 pirttikoski_autotalli_kaikki_yhdessa.txt | awk '{print $1, ($4/($2-$3))}'  
>kond3pva.txt  
tail -168 pirttikoski_autotalli_kaikki_yhdessa.txt | awk '{print $1, ($4/($2-$3))}'  
>kond7pva.txt  
tail -336 pirttikoski_autotalli_kaikki_yhdessa.txt | awk '{print $1, ($4/($2-$3))}'  
>kond14pva.txt  
chmod 755 kond3pva.txt  
chmod 755 kond7pva.txt  
chmod 755 kond14pva.txt
```

```
#Suoritetaan R-skripti joka luo tekstitiedostot  
./r_kond_regana  
chmod 755 kond3en.txt  
chmod 755 kond7en.txt  
chmod 755 kond14en.txt
```

```
#Siistitään ennusteita ja tehdään niistä kertyvä tiedosto  
tail -1 kond3en.txt | awk '{print $2, $3, $4, $5}' >>kond3en_kertyva.txt  
tail -1 kond7en.txt | awk '{print $2, $3, $4, $5}' >>kond7en_kertyva.txt  
tail -1 kond14en.txt | awk '{print $2, $3, $4, $5}' >>kond14en_kertyva.txt  
chmod 755 kond3en_kertyva.txt  
chmod 755 kond7en_kertyva.txt  
chmod 755 kond14en_kertyva.txt
```

```
#Liitetään ennusteet oikeisiin arvoihin  
join kond3pva.txt kond3en_kertyva.txt >kond3enjatot.txt  
join kond7pva.txt kond7en_kertyva.txt >kond7enjatot.txt  
join kond14pva.txt kond14en_kertyva.txt >kond14enjatot.txt  
chmod 755 kond3enjatot.txt  
chmod 755 kond7enjatot.txt  
chmod 755 kond14enjatot.txt
```

```
#Tehdään graafit gnuplotilla
gnuplot plot_lampkond3pva
gnuplot plot_lampkond7pva
gnuplot plot_lampkond14pva
chmod 755 lampkond3pva.png
chmod 755 lampkond7pva.png
chmod 755 lampkond14pva.png

#kopioidaan nettihakemistoon kuvat ja tekstitiedostot
cp -a lampkond3pva.png /var/www/sula/
cp -a lampkond7pva.png /var/www/sula/
cp -a lampkond14pva.png /var/www/sula/

cp -a kond3enjatot.txt /var/www/sula/
cp -a kond7enjatot.txt /var/www/sula/
cp -a kond14enjatot.txt /var/www/sula/
```

```
#!/usr/bin/env Rscript

# Määritetään työhakemisto
setwd("/home/user/regana")

#haetaan tiedot muuttujiin
kond3pva<-read.table("/home/user/regana/kond3pva.txt")
kond7pva<-read.table("/home/user/regana/kond7pva.txt")
kond14pva<-read.table("/home/user/regana/kond14pva.txt")

#Tehdään ennusteen tunti
viimeh<-kond3pva[72,1]
seurh<-seq(as.POSIXct(viimeh, format = "%Y-%m-%d-%H"), length.out=2,
by="hour")
seurh<-format(seurh,"%Y-%m-%d-%H")

#lämpökonduktanssit omaan muuttujaan
kond3<-kond3pva[,2]
kond7<-kond7pva[,2]
kond14<-kond14pva[,2]

#x-akselin arvot regressiosuoralle
luvut172<-1:72
luvut1168<-1:168
luvut1336<-1:336

#Lineaarinen malli
lm.kond3<-lm(as.matrix(kond3)~luvut172)
lm.kond7<-lm(as.matrix(kond7)~luvut1168)
lm.kond14<-lm(as.matrix(kond14)~luvut1336)

#Ennusteet
kond3en<-predict(lm.kond3, newdata=data.frame(luvut172=73), inter-
val="prediction", level=0.95)
kond7en<-predict(lm.kond7, newdata=data.frame(luvut1168=169), inter-
val="prediction", level=0.95)
kond14en<-predict(lm.kond14, newdata=data.frame(luvut1336=337), inter-
val="prediction", level=0.95)

# Luodaan taulukot, jossa ennusteen pvm ja arvot
kond3en.taul<-cbind(seurh[-1], kond3en[1], kond3en[2], kond3en[3])
kond7en.taul<-cbind(seurh[-1], kond7en[1], kond7en[2], kond7en[3])
kond14en.taul<-cbind(seurh[-1], kond14en[1], kond14en[2], kond14en[3])

# Luodaan tekstitiedostot ennusteista
write.table(kond3en.taul, file="kond3en.txt", quote=FALSE, sep=" ")
write.table(kond7en.taul, file="kond7en.txt", quote=FALSE, sep=" ")
write.table(kond14en.taul, file="kond14en.txt", quote=FALSE, sep=" ")
```



```
set term png
set output 'regana.png'
set terminal png font "/usr/share/fonts/truetype/liberation/LiberationSans-
Regular.ttf" size 1000, 500
set xdata time
set timefmt "%Y-%m-%d-%H"
set xtics format "%d.%m"
set autoscale
set ylabel 'Sähkönkulutus'
set xlabel 'Päivämäärä'
set title 'Pirttikosken autotallin sähkönkulutus, lin. reg.analyysin trendin tulos ja
95% ennusteväli'
plot 'regana_kertyva.txt' using 1:3 with lines title 'Kokonaiskulutus',
'regana_kertyva.txt' using 1:4 with lines title 'Lin. reg.analyysi',
'regana_kertyva.txt' using 1:4 with lines title 'Lin. reg.analyysi',
'regana_kertyva.txt' using 1:5 with lines title 'Alaraja', 'regana_kertyva.txt' using
1:6 with lines title 'Yläraja'
```

```
set term png
set output 'lampkond3pva.png'
set terminal png font "/usr/share/fonts/truetype/liberation/LiberationSans-
Regular.ttf" size 1000, 500
set xdata time
set timefmt "%Y-%m-%d-%H"
set xtics format "%d.%m"
set autoscale
set ylabel 'Lämpökonduktanssi (W/C)'
set xlabel 'Päivämäärä'
set title 'Pirttikosken autotallin lämpökonduktanssi, aikasarjan lin. reg.analyysin
ennuste ja 95% ennusteväli'
plot 'kond3enjatot.txt' using 1:2 with lines title 'Oikea lämpökonduktanssi',
'kond3enjatot.txt' using 1:3 with lines title 'Lin. reg.analyysi', 'kond3enjatot.txt'
using 1:4 with lines title 'Alaraja', 'kond3enjatot.txt' using 1:5 with lines title
'Yläraja'
```

```
set term png
set output 'lampkond7pva.png'
set terminal png font "/usr/share/fonts/truetype/liberation/LiberationSans-
Regular.ttf" size 1000, 500
set xdata time
set timefmt "%Y-%m-%d-%H"
set xtics format "%d.%m"
set autoscale
set ylabel 'Lämpökonduktanssi (W/C)'
set xlabel 'Päivämäärä'
set title 'Pirttikosken autotallin lämpökonduktanssi, aikasarjan lin. reg.analyysin
ennuste ja 95% ennusteväli'
plot 'kond7enjatot.txt' using 1:2 with lines title 'Toteutunut lämpökonduktanssi',
'kond7enjatot.txt' using 1:3 with lines title 'Lin. reg.analyysi', 'kond7enjatot.txt'
using 1:4 with lines title 'Alaraja', 'kond7enjatot.txt' using 1:5 with lines title
'Yläraja'
```

```
set term png
set output 'lampkond14pva.png'
set terminal png font "/usr/share/fonts/truetype/liberation/LiberationSans-
Regular.ttf" size 1000, 500
set xdata time
set timefmt "%Y-%m-%d-%H"
set xtics format "%d.%m"
set autoscale
set ylabel 'Lämpökonduktanssi (W/C)'
set xlabel 'Päivämäärä'
set title 'Pirttikosken autotallin lämpökonduktanssi, aikasarjan lin. reg.analyysin
ennuste ja 95% ennusteväli'
plot 'kond14enjatot.txt' using 1:2 with lines title 'Toteutunut lämpökonduktanssi',
'kond14enjatot.txt' using 1:3 with lines title 'Lin. reg.analyysi', 'kond14enjatot .txt'
using 1:4 with lines title 'Alaraja', 'kond14enjatot.txt' using 1:5 with lines title
'Yläraja'
```